arXiv:0810.1212v1 [cs.CL] 7 Oct 2008

Analyse spectrale des textes : détection automatique des frontières de langue et de discours

Pascal Vaillant[1,2] Richard Nock[1] Claudia Henry[1]
(1) GRIMAAG, Université des Antilles-Guyane, 97233 Schœlcher
(2) GEREC-F, Université des Antilles-Guyane, 97233 Schœlcher
{pvaillan,chenry,rnock}@martinique.univ-ag.fr

Résumé Nous proposons un cadre théorique qui permet, à partir de matrices construites sur la base des données statistiques d'un corpus, d'extraire par des procédés mathématiques simples des informations sur les mots du vocabulaire de ce corpus, et sur la syntaxe des langues qui l'ont engendré. À partir des mêmes données initiales, on peut construire une matrice de similarité syntagmatique (probabilités de transition d'un mot à un autre), ou une matrice de similarité paradigmatique (probabilité de partager des contextes identiques). Pour ce qui concerne la première de ces deux possibilités, les résultats obtenus sont interprétés dans le cadre d'une modélisation du processus génératif par chaînes de Markov. Nous montrons que les résultats d'une analyse spectrale de la matrice de transition peuvent être interprétés comme des probabilités d'appartenance de mots à des classes. Cette méthode nous permet d'obtenir une classification continue des mots du vocabulaire dans des sous-systèmes génératifs contribuant à la génération de textes composites. Une application pratique est la segmentation de textes hétérogènes en segments homogènes d'un point de vue linguistique, notamment dans le cas de langues proches par le degré de recouvrement de leurs vocabulaires.

Abstract We propose a theoretical framework within which information on the vocabulary of a given corpus can be inferred on the basis of statistical information gathered on that corpus. Inferences can be made on the categories of the words in the vocabulary, and on their syntactical properties within particular languages. Based on the same statistical data, it is possible to build matrices of syntagmatic similarity (bigram transition matrices) or paradigmatic similarity (probability for any pair of words to share common contexts). When clustered with respect to their syntagmatic similarity, words tend to group into sublanguage vocabularies, and when clustered with respect to their paradigmatic similarity, into syntactic or semantic classes. Experiments have explored the first of these two possibilities. Their results are interpreted in the frame of a Markov chain modelling of the corpus' generative processe(s) : we show that the results of a spectral analysis of the transition matrix can be interpreted as probability distributions of words within clusters. This method yields a soft clustering of the vocabulary into sublanguages which contribute to the generation of heterogeneous corpora. As an application, we show how multilingual texts can be visually segmented into linguistically homogeneous segments. Our method is specifically useful in the case of related languages which happened to be mixed in corpora.

Mots-clefs : classification spectrale continue, segmentation de textes, identification de langue

Keywords: Soft spectral clustering, text segmentation, language identification

1 Introduction

Un corpus nous livre des données brutes sur la syntaxe du système linguistique utilisé pour le produire. Le mot « syntaxe » est employé ici dans l'acception la plus lâche : on entend par là l'ensemble des régularités combinatoires observées, avec une fréquence dépassant un certain seuil, dans la disposition des unités du corpus. Cette conception minimaliste, et purement empirique, de la syntaxe, est d'une part relative à un corpus, et d'autre part limitée à la description de lois statistiques. L'objet épistémologique de « langue » est, dans ce contexte, hors de notre portée : dans un corpus, on peut d'une part avoir plusieurs langues entremêlées, et l'on n'observe jamais d'autre part *toute* la langue, mais seulement des régularités liées à une situation donnée d'usage. Nous considérons donc plus prudemment que nous avons affaire, avec un corpus donné, à un échantillon fourni par un *système génératif* : celui-ci pouvant être considéré, selon les besoins de la description, tantôt comme une langue, tantôt comme un type de discours (langage de spécialité, genre ...), tantôt comme un idiolecte qui peut lui-même être subordonné à un type de discours.

Depuis Saussure, on envisage les régularités de l'ordre de la syntaxe sous deux dimensions possibles : la dimension *syntagmatique*, qui est celle de la disposition d'unités linguistiques dans la chaîne actualisée par la parole, et la dimension *paradigmatique*, qui est celle de l'ensemble des choix possibles entre unités, en fonction des contraintes de sélection, à un point donné de la chaîne. Deux unités linguistiques appartiennent au même *syntagme* si elles sont conjuguées, au sein d'une unité un peu plus ample, dans la même chaîne parlée ; elles appartiennent au même *paradigme* si elles constituent deux choix possibles pour remplir une position de la chaîne dans un contexte commun.

En vertu de ces notions classiques en linguistique générale, il est possible de donner deux définitions de la *similarité* syntaxique de deux unités : l'une est une similarité syntagmatique : elle mesure la probabilité de deux unités de se retrouver associées dans une même chaîne, à deux positions différentes mais voisines ; l'autre est une similarité paradigmatique : elle mesure la probabilité de deux unités de pouvoir partager le même contexte, c'est-à-dire de pouvoir se retrouver alternativement à la même position dans des chaînes contenant par ailleurs les mêmes autres éléments. Selon cette définition, *chien* et *aboie* sont très voisins relativement à une distance syntagmatique, et très éloignés relativement à une distance paradigmatique. À l'inverse, *aboie* et *jappe* sont très voisins relativement à une distance paradigmatique.

En donnant à ces notions des définitions opératoires précises, il est possible de construire des *matrices de dissimilarité* (et respectivement, des *matrices de similarité*) sur l'espace des mots d'un corpus. L'analyse spectrale de ces matrices (analyse des vecteurs propres) fournit ensuite des axes de classification des mots : une *matrice de similarité syntagmatique*, interprétée comme la matrice de transition d'une chaîne de Markov, nous fournit les éléments permettant de regrouper ensemble les mots qui sont souvent voisins les uns des autres sur la même chaîne, et donc d'*identifier les systèmes génératifs* . Une *matrice de similarité paradigmatique* nous fournit les éléments permettant de regrouper ensemble les mots qui partagent souvent le même contexte, et donc d'*identifier les catégories syntaxico-sémantiques* . La présente communication se concentrera sur la première de ces deux analyses, la seconde étant encore dans une phase d'implémentation plus précoce.

Le système présenté ici se concentre sur la tâche de la classification des mots-types (vocables) d'un corpus. En regroupant les mots par proximité syntagmatique, il parvient à des classes de mots qui reflètent leur appartenance à des systèmes génératifs (langues ou discours) distincts.

Contrairement aux approches comparables fondées sur la classification de textes (Lelu, 2004), il n'attribue pas de classe à chaque texte considéré comme un seul objet individuel : il trouve les oppositions entre classes au sein même du corpus qu'il étudie. Ceci ouvre la possibilité d'une segmentation du texte lui-même en systèmes génératifs distincts. Par *systèmes génératifs*, comme dit plus haut, nous entendons, selon les cas, les langues, les discours, les thématiques, les auteurs, ou une combinaison de ces paramètres[1].

L'identification de langue peut être considérée, sous certaines contraintes, comme un problème résolu : pour se limiter à la tâche de l'identification de textes écrits, rédigés dans une seule langue, et lorsque celle-ci est répertoriée dans une liste de modèles connus, on sait que la méthode de statistiques sur les *n*-grammes les plus fréquents est très fiable, et donne des marges d'erreur inférieures à 1 % dès que la longueur du texte analysé dépasse quelques dizaines de caractères. En combinant cette méthode des *n*-grammes avec celle des mots les plus fréquents, on peut augmenter encore la fiabilité de l'identification jusqu'à arriver à une marge d'erreur négligeable (Greffenstette, 1995). Les choses se compliquent lorsque les textes que l'on cherche à étiqueter sont composites ; (Vo, 2004), par exemple, cherche à la fois à segmenter les textes en zones de langue homogène, et à identifier la langue de chacune de ces zones. Cependant, dans de telles approches, il est encore nécessaire de disposer de modèles statistiques des différentes langues connues, acquis après une phase d'apprentissage supervisé. Or nous partons de données brutes, sans aucun modèles préalable. Nous cherchons, dans le cadre de ce travail, à identifier, au sein d'un texte, des langues différentes mais (a) fréquemment entremêlées dans des textes, et (b) proches, au sens où elles partagent une grande quantité d'unités lexicales. Le but est de démêler des langues qui sont proches à la fois génétiquement et « sociolinguistiquement ». C'est notamment le cas dans la littérature antillaise, pour le français et le créole.

Des approches statistiques ont été appliquées à la segmentation automatique de texte pour identifier des segments homogènes (Choi, 2000), sur d'autres plans que celui de la langue, comme par exemple sur le plan du thème ou sur celui de l'auteur. (Utiyama & Isahara, 2001) utilisent notamment une méthode qui définit les frontières des segments de façon à maximiser leur homogénéité interne. (El-Bèze *et al.*, 2005) introduisent le modèle de la chaîne de Markov pour modéliser les transitions entre segments de texte provenant du même auteur.

Des travaux plus proches des nôtres sont celui de (Belkin & Goldsmith, 2002), qui utilisent une forme de classification spectrale pour déterminer des catégories de mots ; et celui de (Pessiot *et al.*, 2004), qui commencent par classer les mots du corpus et se servent de cette classification pour identifier des segments. Cependant, dans ce travail, la méthode de classification fait le choix délibéré de n'assigner chaque mot qu'à un cluster et un seul. Pour notre application, nous avons besoin d'une méthode qui puisse à la fois identifier les principaux regroupements spécifiques, tout en gardant également l'information concernant les mots qui appartiennent à la fois à plusieurs clusters.

Notre méthode de classification spectrale nous offre la possibilité d'une classification *continue*, c'est-à-dire qu'elle n'attribue pas de manière discrète et univoque un mot à une classe, mais quantifie la probabilité d'appartenance d'un mot à chacune des classes. Enfin, une originalité de ce travail réside dans une interprétation probabiliste des coordonnées des axes propres des matrices de similitude.

[1] Pour paraphraser Hjelmslev, notre objectif est de « donner un système d'étiquettes permettant d'appeler un groupe de textes "anglais", un autre "danois", un autre "prose", un autre "poésie", un autre "Peter Andersen" ou "Lars Petersen", etc., sections qui, on le voit aisément, se croisent de plusieurs manières » (Hjelmslev, 1963, p.179).

2 Éléments du modèle

Nous partons du postulat que nous disposons d'un corpus écrit (i.e. d'une production langagière déjà discrétisée en éléments d'expression élémentaires — des caractères) ; et, en outre, que ce corpus est transcrit dans un système d'écriture qui possède déjà une convention de délimitation des unités lexicales. C'est le cas dans les langues dont nous avons étudié des textes, qui sont des langues vivantes transcrites en caractères latins : les langues de cette catégorie ont à notre connaissance généralisé la convention consistant à délimiter les mots par des caractères spéciaux (signes de ponctuation, ou au moins caractère d'espacement). La méthode pourrait être généralisée aux langues n'appliquant pas cette convention — telles le chinois — au prix d'un prétraitement de délimitation des unités lexicales.

Dans ce cadre, nous disposons des catégories pré-théoriques suivantes : le *texte* est une séquence de caractères ; le *mot-occurrence* est défini « mécaniquement », au sein d'un texte, comme une séquence de caractères alphabétiques consécutifs, délimitée à gauche et à droite par des caractères non-alphabétiques. On peut choisir d'inclure, dans une définition étendue de « mot » (les *tokens*), les séquences de chiffres et les signes de ponctuation également représentés en un ou plusieurs exemplaires dans le texte : ce choix est un paramètre d'usage qu'il peut être utile de fixer au dernier moment, en fonction des informations attendues des résultats[2]. Pour l'instant, nous utilisons le terme *mot-occurrence* au sens le plus général, sans nous préoccuper de savoir si nous y incluons les « mots » non-alphabétiques ou non. Les notions suivantes découlent des premières : un *mot-type* (ou *vocable*) est un agencement de caractères alphabétiques qui se retrouve à une ou plusieurs reprises en tant que mot-occurrence dans les textes. Un *corpus* C est un ensemble de textes. Le *vocabulaire* d'un corpus, $\mathcal{V}(C)$ est l'ensemble des mots-types représentés par au moins une occurrence dans le corpus.

Pour simplifier, nous assimilons dans la suite le corpus à la concaténation de tous les textes qui le composent, bien que les deux notions ne soient pas identiques (lors de la collecte d'informations statistiques sur un corpus, on ne compte en effet pas le dernier mot du texte T_k comme « voisin de gauche » du premier mot du texte T_{k+1}). Nous parlons donc dorénavant indifféremment du « texte » comme s'il constituait à lui seul tout le corpus, ce qui simplifie l'exposé des principes de notre travail, sans en modifier fondamentalement le sens.

Soit un texte T constitué d'une séquence de no occurrences $w_1 w_2 ... w_{no}$, choisies parmi un vocabulaire $\mathcal{V}(T) = \{m_1, m_2, ...m_{nt}\}$ ($nt \leq no$). D'un point de vue algébrique, un texte est ni plus ni moins qu'une application surjective f_T de $[1, no] \subset \mathbb{N}$ dans $[1, nt] \subset \mathbb{N}$: on note $f_T(j) = i$ lorsque w_j est une occurrence du mot m_i.

2.1 Matrices

Nous définissons la *matrice de contexte* à la distance k ($k \in \mathbb{Z}$), notée C_k, comme une matrice de nombres entiers, de dimension $nt \times nt$, dans laquelle chaque coefficient $c_k(i, j)$ correspond au nombre de fois où une occurrence du mot j apparaît à la position $p + k$ lorsqu'une occurrence du mot i apparaît à la position p (pour tout $p \in [1, no]$). Par exemple, pour $k = +1$, cette matrice correspond à la matrice de *contexte immédiat à droite* : le coefficient de C_{+1} à la ligne i et à la colonne j, $c_{+1}(i, j)$, contient le nombre de fois où le mot j s'est retrouvé juste après le mot

[2] Pour la délimitation des classes syntaxiques au sein d'une langue, il peut être parfaitement pertinent d'inclure les virgules et les points, qui permettent par exemple de mettre facilement le doigt sur les classes systématiquement présentes en début de phrase ; cette donnée aurait au contraire plutôt tendance à brouiller les choses lors de la délimitation de différentes langues, utilisant toutes deux les mêmes signes de ponctuation.

i dans le texte. De même, C_{-1} correspond à la matrice de *contexte immédiat à gauche*, C_{+2} à la matrice de contexte à droite à deux mots de distance, etc. Conformément à cette définition, C_0 est une matrice qui contient des zéros partout sauf sur la diagonale, et dont les coefficients diagonaux contiennent le nombre d'occurrences de chaque mot. Dans la suite de cet exposé, pour simplifier la notation, nous la noterons D : $D = C_0$, et nous noterons en abrégé d_i ses coefficients diagonaux : $d_i = c_0(i, i)$ correspond au nombre d'occurrences du mot i dans le texte. Il convient par ailleurs de noter que quel que soit k, la somme de tous les coefficients de la i-ième ligne de la matrice C_k, ainsi que la somme de tous les coefficients de la i-ième colonne de cette même matrice, sont toujours égales à d_i : en effet, les coefficients stockés sur la i-ième ligne correspondent à l'ensemble des fois où le mot i a eu tel ou tel voisin à la distance k (donc il y en a au total autant que d'occurrences de m_i dans le texte) ; de la même manière, les coefficients de la i-ième colonne correspondent à l'ensemble des fois où un autre mot a eu le mot i comme voisin à la distance k.

Dans le travail présenté ici, nous cherchons à extraire automatiquement des informations des corpus sans faire au départ aucune hypothèse sur la langue — ou le « système génératif » — dans lequel ceux-ci ont été composés. Ceci implique notamment de nous affranchir de toute hypothèse sur la directionalité de la lecture. Dans cet objectif, nous définissons un mode de lecture « circulaire » de chaque texte : nous supposons que le texte nous est donné comme un espace linéaire statique qu'un « lecteur » peut indifféremment (et aléatoirement) parcourir de gauche à droite ou de droite à gauche. Afin de prendre en compte cette symétrisation, nous définissons une *matrice de voisinage* à la distance k ($k \in \mathbb{Z}$), notée V_k, comme une matrice de nombres entiers, de dimension $nt \times nt$, dans laquelle chaque coefficient $v_k(i, j)$ correspond au nombre de fois où une occurrence du mot i et une occurrence du mot j se retrouvent à une distance de k mots l'une de l'autre dans la chaîne : $v_k(i, j) = c_k(i, j) + c_k(j, i)$. En pratique, pour conserver une homogénéité de norme avec C, il est préférable de diviser ces coefficients par un facteur 2 (dans V chaque occurrence est en effet comptée deux fois) ; pour chaque k, nous définissons donc une nouvelle matrice W_k comme la matrice de dimension $nt \times nt$ et de coefficients : $w_k(i, j) = \frac{1}{2}v_k(i, j) = \frac{1}{2}\Big(c_k(i, j) + c_k(j, i)\Big)$. Ainsi, les sommes par ligne et par colonne de W sont elles aussi égales aux coefficients d_i. La matrice W est l'équivalent de la matrice de contexte, mais avec un sens de lecture rendu aléatoire : c'est une matrice de contexte équidirectionnelle.

L'étape suivante est de ramener ces informations, extraites d'un corpus donné, à un modèle abstrait indépendant de la taille du texte. Pour cela, il faut normaliser les informations sur le nombre de cas de voisinages observés autour du mot i, en les divisant par le nombre d'occurrences de ce mot. On définit donc une *matrice de probabilité de transition* à la distance k, notée P_k, comme étant la matrice de nombres réels, de dimension $nt \times nt$, et dont les coefficients $p_k(i, j)$ correspondent à la probabilité qu'une occurrence du mot m_j soit observée à une position $p \pm k$ sachant qu'une occurrence du mot m_i a été observée à la position p : $p_k(i, j) = \frac{1}{d_i}w_k(i, j)$. En termes de multiplication de matrices, la matrice P se définit donc globalement par : $P_k = D^{-1}W_k$. La matrice P_k ainsi définie a un certain nombre de propriétés intéressantes qui sont détaillées en § 2.2 et § 3.

Par ailleurs, avec les informations de base tirées des matrices de contexte C_k, on peut construire des matrices de dissimilarité et de similarité paradigmatiques entre les mots de $\mathcal{V}(C)$.

Tout d'abord, on définit pour chaque position contextuelle k une grandeur appelée *dissimilarité des contextes du mot i et du mot j à la position k*, qui correspond à la proportion de mots spécifiques au contexte à la position k de i ou à celui de j, rapportée au nombre total de mots pouvant apparaître dans les contextes à la position k de l'un aussi bien que de l'autre :

$$\delta_k^c(i,j) = \frac{\sum_{x=1}^{nt} |c_k(i,x) - c_k(j,x)|}{\sum_{x=1}^{nt}(c_k(i,x) + c_k(j,x))} = \frac{\sum_{x=1}^{nt} |c_k(i,x) - c_k(j,x)|}{d_i + d_j}$$

Pour prendre l'exemple de $k = +1$: $\delta_{+1}^c(i,j)$ correspond au cardinal de la différence symétrique des contextes immédiats à droite de m_i et de m_j, divisé par le cardinal de l'union de ces deux contextes (ou encore : au nombre de mots-occurrences apparaissant seulement derrière m_i ou seulement derrière m_j, divisé par le nombre total de mots-occurrences apparaissant derrière m_i ou m_j — c'est-à-dire divisé par la somme du nombre d'occurrences de m_i et du nombre d'occurrences de m_j). Dans le cas particulier de $k = 0$: δ_0^c se ramène à : $\delta_0^c(i,j) = 0$ si $i = j$; $\delta_0^c(i,j) = 1$ si $i \neq j$.

On peut ensuite définir une *dissimilarité contextuelle* (ou *dissimilarité paradigmatique*) prenant en compte les contextes d'un intervalle $I = [k_1, k_2]$, comme une somme pondérée des dissimilarités contextuelles δ_k^c pour tous les $k \in I$. Par exemple si les poids valent 1, $\delta^c(i,j) = \sum_{k \in I} \delta_k^c(i,j)$.

Une matrice de *similarité contextuelle* S peut alors être construite en transformant la dissimilarité δ^c en similarité, par la formule simple $s(i,j) = 1 - \delta^c(i,j)$ ($\delta^c(i,j)$ étant comprise dans $[0,1]$, $s(i,j)$ l'est aussi).

2.2 Dissimilarités et similarités

Il est possible de montrer que δ^c, définie comme ci-dessus (§ 2.1), est une véritable distance sur $\mathcal{V}(C)$: pour commencer, elle prend ses valeurs sur $\mathbb{R}^+$, et elle est symétrique. L'inégalité triangulaire est démontrable, mais nous n'en inclurons pas la preuve ici faute de place. Enfin, si l'intervalle I considéré ci-dessus contient $k = 0$, alors δ^c vérifie également l'axiome de séparation ($\forall i, j \in \mathcal{V}(C), \delta^c(i,j) = 0 \Leftrightarrow i = j$), puisque même si deux vocables distincts m_i et m_j ont exactement les mêmes contextes sur les autres positions $k \in I$, la définition de $\delta_0^c(i,j)$ suffit à les discriminer. Cette distance sur l'espace des mots ouvre la voie à différentes possibilités d'algorithmes de minimisation. En outre, il est intéressant de noter que cette distance possède une interprétation en termes bayésiens : $\delta^c(i,j)$ correspond en effet à la probabilité de se trouver dans un contexte qui soit spécifique à l'un des deux mots m_i ou m_j, sachant que l'on est dans une position contextuelle qui permet au moins l'un des deux, et peut-être les deux : bref, $\delta^c(i,j)$ représente la probabilité que le contexte courant *discrimine* m_i et m_j au sein de leur paradigme commun. Cette interprétation a des implications en termes de définition de catégories syntaxiques et sémantiques que nous n'avons pas fini d'explorer.

Revenons maintenant à la matrice de probabilité de transition P, définie plus haut dans § 2.1. Dans la suite, pour alléger les notations, nous considérons le cas particulier où $k = 1$, et sauf indication contraire, nous notons simplement P pour P_1 et W pour W_1. Ce qui en est dit est généralisable sans difficulté aux autres valeurs possibles de k.

Tout d'abord, on peut observer que les coefficients de P, les $p(i,j)$, possèdent certaines propriétés d'une *fonction de similarité* sur l'ensemble des mots : c'est une fonction de $\mathcal{V}(C) \times \mathcal{V}(C)$ dans $]0,1] \subset \mathbb{R}^+$. On peut définir à partir de cette fonction une fonction de *dissimilarité*, grâce à une transformation du type $\delta(i,j) = 1 - p(i,j)$, ou $\delta(i,j) = (1 - p(i,j))/p(i,j)$, définie de $\mathcal{V}(C) \times \mathcal{V}(C)$ dans $\mathbb{R}^+$, qui vérifie l'axiome de séparation ($\delta(i,j) = 0 \Leftrightarrow i = j$) et l'axiome de symétrie ($\forall i, j, \delta(i,j) = \delta(j,i)$). Cependant cette fonction ne vérifie pas l'inégalité triangulaire[3] qui en ferait une *distance* à proprement parler, et ne peut donc pas directement servir de critère

[3] On ne peut pas affirmer, connaissant un mot m_x et un mot m_y, qu'il est impossible de trouver un mot m_z tel que

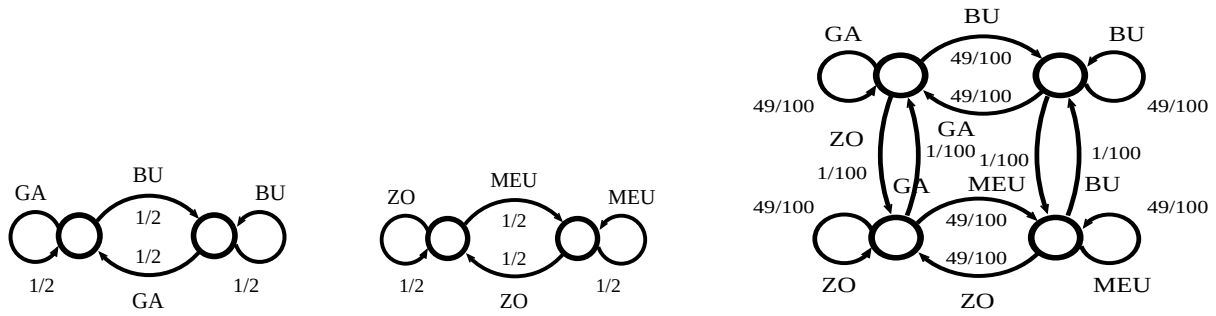

FIG. 1 – *À gauche, deux exemples de processus génératifs élémentaires : (a) l'un produit des chaînes comme : « GA BU BU BU BU GA BU GA BU BU BU BU BU BU BU BU GA GA GA BU » ; (b) l'autre des chaînes comme : « ZO ZO ZO MEU ZO MEU ZO MEU MEU ZO MEU MEU MEU MEU MEU ZO MEU ZO ZO ZO ». À droite : (c) Processus génératif mixte produisant des chaînes comme : « BU GA GA BU BU GA BU BU GA ZO MEU MEU ZO MEU MEU ZO MEU MEU ZO ZO » ; la probabilité que la « parole » passe de l' « auteur » disant « GA-BU » à l' « auteur » disant « ZO-MEU » est de 2 %.*

de base à un algorithme de minimisation. Véronis (2003), qui utilise une fonction de similarité proche de la nôtre pour cartographier la proximité syntagmatique de mots sur de grands corpus, attaque le problème par des heuristiques de détection de composantes fortement connexes dans des grands graphes de mots co-occurrents. Notre approche est différente et fait appel à des méthodes de classification spectrale continue, en partant d'une autre propriété intéressante de P, dont il va être question en § 3.

3 Interprétation en termes de chaînes de Markov

La matrice P constitue, d'après un lemme classique (cf. par exemple (Petruszewycz, 1981)), l'*estimation par maximum de vraisemblance*, sur l'ensemble des bigrammes observés, de la matrice de transition de la chaîne de Markov engendrant le texte T.

Revenons un instant sur la notion que nous cherchons à appréhender en parlant de *système génératif*. Comme nous l'avons dit plus haut, il peut s'agir d'une langue, d'un genre, d'un idiolecte ... D'un point de vue empirique, nous n'avons pas d'autre moyen de caractériser cette variable que les n-grammes que nous observons dans le corpus. Les chaînes de Markov peuvent donc se révéler un outil de modélisation tout à fait adapté pour la représenter. Pour simplifier, nous considérons pour l'instant uniquement les probabilités des bigrammes[4]. Dans ce cadre, il est facile de se représenter ce que signifie un système génératif : il suffit de s'imaginer un « auteur » comme un agent simpliste effectuant un parcours aléatoire le long des transitions d'une chaîne de Markov. Le résultat du parcours est la chaîne engendrée. Nous donnons fig. 1 (a) et (b) deux exemples de ce que peuvent produire des « auteurs » simplistes parcourant de telles chaînes de Markov.

Un texte composite peut alors être conçu comme le résultat du parcours aléatoire d'une chaîne de Markov complexe, résultant d'une combinaison de plusieurs chaînes de Markov plus compactes et plus homogènes, comme illustré dans la fig. 1 (c). Le but de notre tâche de classification peut alors être conçu comme un travail de *séparation* des deux processus génératifs, qui fonctionne en attribuant à chaque état une probabilité d'appartenance à l'une ou l'autre des

$p(x,z)+p(z,y) > p(x,y)$, en d'autres termes tel que la probabilité de transition de m_x à m_y *en passant par* m_z soit plus grande que la probabilité de passer directement de m_x à m_y. Ce cas de figure est au contraire tout à fait courant : dans le composé *match de barrage* (exemple emprunté à Véronis), $p(match, de) + p(de, barrage) > p(match, barrage)$.

[4]Dans ce contexte, bigramme signifie : « groupe de deux *mots* consécutifs ».

sous-chaînes.

Notre méthode de classification se fonde ensuite sur le principe de la classification *spectrale*, c'est-à-dire fondée sur la répartition des mots le long des principaux axes propres de la matrice P. Remarquons tout d'abord que P, sans être symétrique, est définie par le produit de deux matrices réelles symétriques (D^{-1} et W, cf. § 2.1), et qu'elle admet donc des valeurs propres réelles. D'autre part, par construction, P est *stochastique par lignes*, c'est-à-dire que la somme de tous les coefficients d'une même ligne est toujours égale à 1 (c'est la somme des probabilités de transition d'un mot m_i à un mot suivant). Ceci lui confère une autre propriété, qui est d'être de norme 1, et d'admettre également 1 comme plus grande valeur propre. Les autres valeurs propres appartiennent toutes à $]0, 1[$ et peuvent être (sans perte de généralité) considérées comme classées par ordre décroissant : λ_2, λ_3, etc. (il y en a nt en tout).

Il convient de noter que le problème de la recherche d'une grande valeur propre de P est équivalent à celui de la recherche d'une valeur propre proche de zéro pour le problème de valeurs propres généralisé $(D - W)\boldsymbol{y} = \mu D\boldsymbol{y}$ (à une multiplication par D^{-1} près, et en notant $\mu = 1 - \lambda$). Ce problème résulte de la réécriture de la contrainte de minimisation d'un *critère de coût normalisé*, utilisé en classification pour modéliser la recherche d'un minimum de conductance entre classes. La conductance entre une classe k et son complémentaire y est évaluée comme la somme, pour toutes les paires de mots (i, j), d'une distance représentant la probabilité d'appartenance commune à la classe k, pondérée par le poids de la transition possible entre i et j : $\kappa_k(Z) = \sum_{i,j=1}^{v} w_{ij}(z_{ik} - z_{jk})^2$ (z_{ij} dénote la fonction caractéristique de l'appartenance du mot i à la classe k). Le critère de coût normalisé a notamment été introduit par (Shi & Malik, 2000) pour des applications de segmentation d'image, et également utilisé par (Belkin & Goldsmith, 2002) pour le clustering de mots français et anglais. La classification spectrale discrète procède ensuite à la recherche d'une fonction de seuil ; dans notre application, nous nous intéressons à une classification continue, donc nous allons utiliser directement les vecteurs propres de P.

Les axes propres d'une matrice peuvent être caractérisés par des vecteurs de norme quelconque, pourvu qu'ils soient sur le bon axe. Les fonctions de calcul d'algèbre linéaire que nous utilisons (paquetage LAPACK) fournissent des vecteurs propres $\boldsymbol{y}'_k$ normalisés de telle sorte que $\|\boldsymbol{y}'_k\|_2 = 1$. Notons $y'_k(i)$ les nt coordonnées des vecteurs $\boldsymbol{y}'_k$. Soient maintenant $\boldsymbol{y}_k$ ($k \in [1, nt]$) les vecteurs propres de P définis par multiplication des $\boldsymbol{y}'_k$ par une constante scalaire définie pour chacun d'entre eux par $1/\sqrt{\sum_{i=1}^{nt} d_i y'_k(i)^2}$. Si nous notons $y_k(i)$ les nt coordonnées des vecteurs $\boldsymbol{y}_k$, ces vecteurs vérifient par construction : $\sum_{i=1}^{nt} d_i y_k(i)^2 = 1$ (ou encore : $\boldsymbol{y}^\top D\boldsymbol{y} = \mathbf{1}$). Ceci signifie que $d_i y_k(i)^2$ a les propriétés d'une *distribution de probabilité* sur $\mathcal{V}(C)$.

En tant que vecteurs propres, ces $\boldsymbol{y}_k$ vont être caractérisés par des coordonnées positives ou négatives qui correspondent à une corrélation de chaque mot avec une composante principale donnée ; cependant nous voulons insister sur l'autre interprétation possible des vecteurs propres $\boldsymbol{y}_k$, qui est spécifique à l'approche présentée. Nous pouvons considérer chaque axe propre comme une classe (appelons-la $\mathcal{L}_k$), chaque classe comportant *tous* les mots, mais avec une « probabilité d'appartenance » qui est donnée, pour chaque mot m_i, par $d_i y_k(i)^2$. Sous ce point de vue, la grandeur $d_i y_k(i)^2$ s'interprète donc comme la *probabilité d'observer le mot m_i sachant qu'on est dans la classe $\mathcal{L}_k$* : $\mathbf{Pr}(m_i|\mathcal{L}_k)$. Il est intéressant d'observer au passage que le premier vecteur propre $\boldsymbol{y}_1$, généralement rejeté comme trivial, correspond en fait dans cette interprétation à la classe globale du corpus observé, $\mathcal{L}_1$, contenant tous les mots avec une probabilité qui est précisément leur probabilité d'apparition dans le corpus ($y_1(i) = d_i / \sum_{i=1}^{nt} d_i$). Ensuite, pour $k > 1$, nous voyons se former des classes qu'il est possible d'interpréter comme représentant l'appartenance de chaque mot à tel ou tel système génératif.

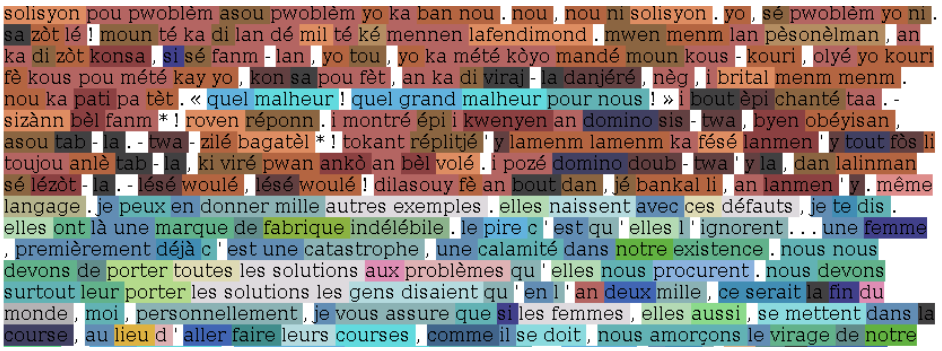

FIG. 2 – *Une visualisation par codes de couleur de l'appartenance de chaque mot aux classes correspondant aux axes propres de rang 2, 3 et 4, sur l'exemple d'un texte bilingue français et créole martiniquais (roman* Lavwa Egal — La voix égale*, de Thérèse Léotin, 2003). Sur ce schéma, les grandeurs représentées sont proportionnelles aux* carrés *des coordonnées de chaque mot sur les vecteurs propres.*

4 Applications et Conclusion

Nous avons utilisé les méthodes décrites plus haut pour classifier automatiquement les mots de corpus composites comportant des échantillons de plusieurs langues entremêlées. Nous nous sommes en particulier intéressés au cas de textes bilingues en français et en créole. Afin de mieux visualiser les résultats, nous avons adopté une méthode consistant à faire ré-afficher tous les mots dans l'ordre du texte, en les faisant apparaître sur un fond coloré dont le codage vectoriel RVB correspond à l'affichage des coordonnées du vocable sur trois axes propres significatifs (les meilleurs résultats étant en général donnés par le choix des axes propres correspondant aux valeurs propres λ_2, λ_3 et λ_4). Un exemple de résultat de ce type de visualisation est donné fig. 2. Notons que ce procédé ne permet pas de visualiser des *langues* à proprement parler, puisque le système a créé des classes de manière totalement non supervisée, et que ce sont ces classes qui servent de base à l'affichage ; pour attribuer une *langue*, choisie dans un ensemble prédéfini, à chaque mot du corpus, il faut effectuer une deuxième étape d'apprentissage, supervisée cette fois, qui nécessite l'étiquetage préalable de quelques mots représentatifs de chacune des langues manifestées.

Les positions respectives des mots les plus fréquents du corpus sur les deux premiers axes propres peuvent également être représentées sur un diagramme bidimensionnel comme celui de la fig. 3.

Les méthodes mises en œuvre dans ce travail ont prouvé leur efficacité sur des problèmes génériques, en se limitant volontairement à des données de base extrêmement simples (matrices de transition sur des bigrammes). Ils arrivent à identifier des sous-systèmes génératifs à partir de corpus bruts, sans aucune information enrichie. La principale voie d'amélioration que nous comptons explorer est celle de l'enrichissement mutuel des deux approches présentées (catégorisation syntagmatique et paradigmatique) dans le cadre d'un processus itératif, afin d'aller vers l'annotation automatique ou semi-automatique des corpus — cette annotation servant elle-même de base à une meilleure segmentation. L'objectif est d'arriver à une plate-forme d'acquisition automatique d'information sur les langues ou sur les genres.

Références

BELKIN M. & GOLDSMITH J. (2002). Using eigenvectors of the bigram graph to infer morpheme identity. In *Morphological and Phonological Learning: Proc. of the* 6th *Workshop of the ACL SIG in Computational Phonology (SIGPHON)*, p. 41–47.

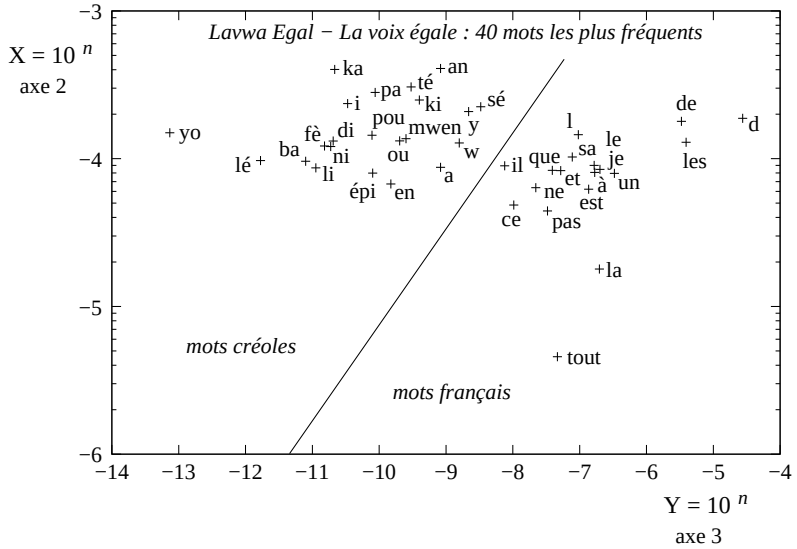

FIG. 3 – *Les 40 mots les plus fréquents de* Lavwa egal — La voix égale *, développés sur les deux premiers axes principaux de valeur propre < 1 . N.B. “en”, “y”, “an”, “tout” et “la” sont tout à la fois des mots créoles et des mots français (parmi eux, “y”, “an” et “tout” apparaissent plus fréquemment dans des contextes de phrases créoles que dans des contextes de phrases françaises).*

CHOI F. Y. Y. (2000). Advances in domain independent linear text segmentation. In *Proceedings of NAACL*, p. 26–33.

EL-BÈZE M., TORRES-MORENO J. M. & BÉCHET F. (2005). Peut-on rendre automatiquement à César ce qui lui appartient ? application au jeu du Chirand-Mitterrac. In M. JARDINO, Ed., *Actes de TALN 2005 (Traitement automatique des langues naturelles)*, p. 125–134, Dourdan: ATALA LIMSI. Atelier DEFT’05.

GREFFENSTETTE G. (1995). Comparing two language identification schemes. In *Journées Internationales d’Analyse des Données Textuelles (JADT)*, p. 263–268.

HJELMSLEV L. (1963). *Degrés Linguistiques*, In *Le langage*, p. 175–181. Arguments. Les Éditions de Minuit: Paris.

LELU A. (2004). Analyse en composantes locales et graphes de similarité entre textes. In *Journées Internationales d’Analyse des Données Textuelles (JADT)*, p. 737–742.

PESSIOT J.-F., CAILLET M., AMINI M.-R. & GALLINARI P. (2004). Apprentissage non-supervisé pour la segmentation automatique de textes. In *Conférence en Recherche d’Information et Applications (CORIA’04)*, p. 1–8.

PETRUSZEWYCZ M. (1981). *Les chaînes de Markov*. Travaux de linguistique quantitative. Genève / Paris: Slatkine.

SHI J. & MALIK J. (2000). Normalized cuts and image segmentation. *IEEE Trans. on Pattern Analysis and Machine Intelligence*, **22**(8), 888–905.

UTIYAMA M. & ISAHARA H. (2001). A statistical model for domain-independent text segmentation. In *Proc. of the 39 th Meeting of the Association for Computational Linguistics*, p. 491–498.

VÉRONIS J. (2003). Cartographie lexicale pour la recherche d’information. In B. DAILLE, Ed., *Actes de TALN 2003 (Traitement automatique des langues naturelles)*, p. 265–274, Batz-sur-mer: ATALA IRIN.

VO T.-H. (2004). Construction d’un outil pour identifier et segmenter automatiquement un texte hétérogène en zones homogènes. In *Recherche Innovation Vietnam et Francophonie*, p. 175–178.